

PATENT ABSTRACTS OF JAPAN

(11)Publication number : 04-175964

(43)Date of publication of application : 23.06.1992

(51)Int.Cl. G06F 15/18
G06F 15/70


(21)Application number : 02-302440 (71)Applicant : HITACHI LTD

(22)Date of filing : 09.11.1990 (72)Inventor : ABE SHIGEO
SHIKAYAMA MASAHIRO
TAKENAGA HIROSHI
MOROOKA YASUO
KAWAKAMI JUNZO
TAKATO MASAO

(54) STRUCTURE DEVICE FOR NEURAL NETWORK AND PATTERN RECOGNITION
DEVICE USING NEURAL NETWORK

(57)Abstract:

PURPOSE: To make the constitution of a neural network arithmetic means irreducible and necessary by simple arithmetic by providing a means which optimizes the neural network according to sets of tutor data and specific conditions which are given previously. CONSTITUTION: A storage means 103 and a neural network system optimum design means 105 are provided. The neural network arithmetic means 102 processes an output signal corresponding to an input signal according to the constitution of the multi-layered neural network. Combinations of desired outputs to inputs (tutor data) are



stored in the storage means 103 and the neural network system optimum design means 105 structures the neural network which satisfies the conditions according to the specified conditions and teacher data. Consequently, the neural network can be structured analytically and constitution which hardly causes misrecognition is obtained.

⑥ 公開特許公報(A) 平4-175964

⑦ Int. Cl.¹

識別番号

庁内整理番号

⑧ 公開 平成4年11月22日

G 06 F 15/18
15/70

4 6 5 A

8945-5L
9071-5L

審査請求 未請求 請求項の数 28 (全28頁)

⑨ 発明の名称 ニューラルネットの構築装置及びニューラルネットを用いたパターン認識装置

⑩ 特 願 平2-302440

⑪ 出 願 平2(1990)11月9日

特許法第30条第1項適用 平成2年8月15日、社団法人情報処理学会発行の「第41回(平成2年度期)全国大会講演文集(2)」に発表

⑫ 発 明 者 阿 部 重 夫 茨城県日立市久慈町4026番地 株式会社日立製作所日立研究所内

⑬ 発 明 者 鹿 山 昌 宏 茨城県日立市久慈町4026番地 株式会社日立製作所日立研究所内

⑭ 出 願 人 株式会社日立製作所 東京都千代田区神田駿河台4丁目6番地

⑮ 代 理 人 菅 野 正 小 川 勝 男 外2名

最終頁に続く

明 細 書

1. 発明の名称

ニューラルネットの構築装置及びニューラルネットを用いたパターン認識装置

2. 特許請求の範囲

1. 入力データに対する望ましい出力データを教師データとし、いくつかの教師データの入出力関係をいくつかのニューロンを多層に接続したニューラルネットに記憶させるものにおいて、教師データの順と予め与えられた所定の条件とによりニューラルネットを最適化する方法を有し、与えられた条件を満足するニューラルネットを構成することを特徴とするニューラルネットの構築装置。
2. 請求項1記載のニューラルネット構築装置において、ニューラルネットの規模を最小化する条件を満たすようにニューラルネットを構成することを特徴とするニューラルネット構築装置。
3. 請求項2記載のニューラルネットの構築装置において、最小規模のパターン認識を行なうネ

ットを構築するために、入力層と中間層とニューロン間の重みを逐次パターンシフト法による設定することを特徴とするニューラルネットの構築装置。

4. 請求項3記載のニューラルネットの構築方法及び装置において、中部層と出力との間の重みを不等式を解くことにより求めることを特徴とするニューラルネットの構築方法及び装置。
5. 請求項3記載のニューラルネットの構築装置において、ニューラルネット最適化の手順を設けたことを特徴とするニューラルネットの構築装置。
6. 請求項1又は2記載のニューラルネット構築装置において、前記ニューロンの数を最小化する条件を満たすようにニューラルネットを構成することを特徴とするニューラルネット構築方法及び装置。
7. 請求項1、2又は3記載のニューラルネットの構築装置において、前記ニューロンの数を最小化する条件を満たすようにニューラル

ネットワークを構築することを特徴とするニューラルネットワークの構築装置。

8. 請求項7、および8記載のニューラルネットワーク構築装置において、前記多層に接続したニューラルネットワークのうち、中間層のニューロン数を最小するという条件を満たすようにニューラルネットワークを構築することを特徴とするニューラルネットワークの構築装置。

9. 請求項7、8、および9記載のニューラルネットワーク構築装置において、前記入力データに含まれる複数の信号の中から、ネットワークの性能に与える影響の少ない信号を検出し、入力層のニューロン数を、前記入力データから検出された信号を除いた数に对应して設定する入力層信号最適化手段を設けたことを特徴とするニューラルネットワークの構築装置。

10. 請求項9記載のニューラルネットワーク構築装置において、前記入力信号最適化手段は、前記入力データと前記出力データの相関関係を評価し、入力データに含まれる各信号のうち出力データ

量において、前記中間層ニューロン数最適化手段は、入出力関係の記憶を終了したニューラルネットワークに、前記入力データを逐次入力し、中間層ニューロンの出力を得、当該出力を解析した情報に基づいて、前記中間層のニューロン数を決定することを特徴とするニューラルネットワークの構築装置。

14. 請求項9乃至11のうち何れかに記載のニューラルネットワークの構築装置において、教師データ及び前記ニューラルネットワークの評価に用いる入力データと出力データの組み合わせを覚え、前記入力信号最適化手段により設定された入力データと、出力データとの関係を前記ニューラルネットワークに記憶させ、前記入力信号最適化手段は、前記ニューラルネットワークの評価結果に基づいて更に入力データに含まれる複数の信号の中からネットワークの性能に与える影響の少ない信号を検出し、入力層のニューロン数を設定することを特徴とするニューラルネットワークの構築装置。

15. 請求項11および13項のうち何れかに記載の

の決定に貢献していないものを排除する機能と前記入力データの各信号の線形関係を評価し、他の信号により良好に移形変換できるものを異なる信号として排除する機能を備えたことを特徴とする、ニューラルネットワーク構築装置。

11. 請求項9記載のニューラルネットワークの構築装置において、前記入力層信号最適化手段は、前記入力データに含まれる各信号を1つずつ変動させたときのニューラルネットワークの出力データを観測し、入力データに含まれる各信号のうち出力データに影響を与えないものを排除する機能を備えたことを特徴とするニューラルネットワークの構築装置。

12. 請求項5記載のニューラルネットワーク構築装置において、前記ニューラルネットワーク最適化手段は、前記中間層のニューロン数を逐次減らして設定する中間層ニューロン数最適化手段を設けたことを特徴とするニューラルネットワークの構築装置。

13. 請求項12記載のニューラルネットワークの構築装

置において、前記ニューラルネットワーク最適化手段は、前記入力信号最適化手段と前記中間層ニューロン数最適化手段を覚え、前記入力信号最適化手段により決定された入力データに基づいて前記中間層ニューロン数最適化手段で中間層ニューロン数の最適化を行うことを特徴とするニューラルネットワークの構築装置。

16. 請求項9記載のニューラルネットワークの構築装置において、前記ニューラルネットワーク最適化手段は、入力層のニューロン数と中間層のニューロン数との値を最小化することを特徴とするニューラルネットワークの構築装置。

17. 請求項11記載のニューラルネットワークの構築装置において、前記与えられ所定の条件とは、ニューラルネットワークの学習時間を指定された時間内で終了するという条件であることを特徴とするニューラルネットワークの構築装置。

18. 請求項17記載のニューラルネットワークの構築装置において、指定された学習時間内で学習を終

すもよって入力データの信頼数及び学習回数
を決定する手段を設けたことを特徴とするニュー
ラルネットの構築装置。

19. 請求項1記載のニューラルネットの構築装置
において、前記与えられた漸定条件とは、教師
データ以外に入力データに対する出力誤差を
最小化する条件であることを特徴とする
ニューラルネットの構築装置。

20. 請求項19記載のニューラルネットの構築装
置において、前記出力誤差を最小化する条件を
満たすよう入力と中間層ニューロンの間の重み
を入力パターンを分離するように設定すること
を特徴とするニューラルネットの構築装置。

21. ニューロンを多層に接続し、ニューロン間を
重みをもったシナプスで結合したニューラルネ
ットを用いてパターン認識する装置において、
入力と中間層ニューロンの間の重みをパターン
を分離する超平面あるいはそれに平行な平面に
対応するように設定したことを特徴とするパ
ターン認識装置。

ットに対して学習を実行させるものにおいて、
中間層と出力層ニューロンの間の重みを不等式
を解くことにより求める手段を有することを特
徴とするニューラルネットの学習装置。

26. ニューロンを多層に接続し、ニューロン間を
重みをもったシナプスで結合したニューラルネ
ットに対して学習を実行させるものにおいて、
前記学習の収束の判定を、教師データに対する
ニューラルネットの全出力が予め設定された指
定値を超えた場合に、収束計算を終了すること
を特徴とするニューラルネットの学習装置。

27. ニューロンを多層に接続し、ニューロン間を
重みをもったシナプスで結合したニューラルネ
ットに対して学習を実行させるものにおいて、
入力と中間層ニューロンの間の重みをパターン
を分離する超平面あるいはそれに平行な平面に
対応するように学習させることを特徴とする
ニューラルネットの学習方法。

28. ニューロンを多層に接続し、ニューロン間を
重みをもったシナプスで結合したニューラルネ

22. 請求項21記載のパターン認識装置において、
認識結果に誤認識が生じた場合に中間層入力ある
いは出力と対応するパターン間の教師データの
中間層入力あるいは出力とを比較することによ
り、前記誤認識を引き起こした中間層ニューロ
ンを検出することを特徴とするパターン認識装
置。

23. 請求項22記載のパターン認識装置において、
前記検出された中間層ニューロンと入りの間の
重みをパターン分離できるようにチューニング
することを特徴とするパターン認識装置。

24. ニューロンを多層に接続し、ニューロン間を
重みをもったシナプスで結合したニューラルネ
ットに対して学習を実行させるものにおいて、
入力と中間層ニューロンの間の重みをパターン
を分離する超平面あるいはそれに平行な平面に
対応するように学習させる手段を有することを
特徴とするニューラルネットの学習装置。

25. ニューロンを多層に接続し、ニューロン間を
重みをもったシナプスで結合したニューラルネ

ットに対して学習を実行させるものにおいて、
中間層と出力層ニューロンの間の重みを不等式
を解くことにより求めることを特徴とするニュー
ロンネットの学習方法。

3. 発明の詳細な説明

【産業上の利用分野】

本発明は、多層ニューラルネットを構築する装
置、並びに多層ニューラルネットの各種の応用装
置（認識、予測、推定、関数近似、制御等）を行う
装置に関する。

【従来の技術】

ニューラルネットワークを用いてパターン認識、
予測、推定、関数近似、制御等を行う方法につ
いて、エム・アイ・ティー プレス（米国カリ
フォルニア州）から出た第2巻（Parallel Distributed
Processing, Vol. 2, 2nd Edition, Cambridge
MA, 1986）pp. 3-22において論じられている。

ここでパターン認識を例にとってニューラルネ

ットを説明する。ニューラルネットは、ニューロンをカスケード状に各層に結合したもので第2図は3層ニューラルネットの例を示している。図において1000、1001は入力ニューロン、1003、1004は中間層ニューロン、1005、1007は出力ニューロン、1002、1006はバイアスニューロンである。入力及びバイアスニューロンは、入力をそのまま出力するが、中間層及び出力ニューロンは、第3図に示すようなシグモイド関数と呼ばれる飽和特性のある入出力関係を持ち入力を x 、出力を z とすると

$$z = f(x) = \frac{1}{1 + \exp(-x/T)} \quad (1)$$

となる。ここで T は、シグモイド関数の傾きを決める定数である。

入力側から各層の番号を打つとし、 i 番目の層 j 番目のニューロンの入力、及び出力を各々 $x_{ij}(i)$ 、 $z_{ij}(i)$ とすると、入力ニューロンの入出力関係は、上述したことにより、

$$x_{ij}(i) = z_{ij}(i) \quad j=1, \dots, n(i), i=1$$

$z_{ij}(i-1) = (z_{i1}(i-1), \dots, z_{i,n(i-1)}(i-1))^t$ は $(i-1)$ 層ニューロンの出力ベクトルで、 t は行列の転置を示している。

上記のニューラルネットで入力データを $n(3)$ 組のパターンで分類する場合は、 i 番目の出力ニューロンをパターン i に対応させ、ある入力に対して i 番目の出力ニューロンが1で他が0のときパターン i であるというように判定する。このようにパターン分類ができるためには、重み $w_{ij}(i)$ ($i=2, 3$) を適切に決める必要があるが、そのために入出力データを教師データとして学習により重みを決める。今 m 組の教師データの組 $\{(x_{ij}(1), s_{ij})\}$

$$i=1, \dots, n(1), j=1, \dots, n(2), k=1, \dots, m \quad (3)$$

とすると、

$$E = \sum_{i=1}^n \sum_{j=1}^{n(i)} \sum_{k=1}^m (z_{ij}(3) - s_{ij})^2 \rightarrow \min \quad (6)$$

となるように重み $w_{ij}(i)$ を決める。但し $z_{ij}(3)$ は教師データ入力 $x_{ij}(1)$ に対応する出力ニ

$$z_{ij}(i+1)(i) = 1 \quad (2)$$

となる。ここで $n(i)$ は i 番目の層への入力数であり、 $z_{i,n(i+1)}(i)$ はバイアス項となる。

第2、及び第3層の i 番目のニューロンの出力は、

$$z_{ij}(i) = f(x_{ij}(i)) \quad j=1, \dots, n(i), i=2, 3$$

$$z_{i,n(i+1)}(i) = 1 \quad i=2, 3 \quad (3)$$

となる。ここで $z_{i,n(i+1)}(i)$ はバイアス項である。各層間のニューロンはシグナスを介して完全に結合されており、各々シグナスは重みを持ち、ニューロンの出力にその重みを乗じたものが次のニューロンへの入力となる。従って第2、3層目の i 番目のニューロンへの入力は次式で与えられる。

$$x_{ij}(i) = w_{ij}(i-1) \cdot z_{ij}(i-1) \quad j=2, 3, i=1, \dots, n(i-1) \quad (4)$$

但し、

$$w_{ij}(i-1) = (w_{ij1}(i-1), \dots, w_{ijn(i-1)}(i-1))$$

は重みベクトルで $w_{ijn(i-1)}(i-1)$ は $(i-1)$ 番目の層の k 番目のニューロンと i 番目の層の j 番目のニューロンの間のシグナスの重みであり、

ニューロンの出力である。重みを決める方法としては、上記文献に示されている逆伝播法が広く用いられている。この方法では、1組の教師データの入力 $x_{ij}(1)$ 、 $i=1, \dots, n(1)$ に対して出力 $z_{ij}(3)$ が n_{ij} 、 $j=1, \dots, n(3)$ に近づくように出力側から順次入力側に重みを修正し、それが終わったら次の教師データについてまた同じ手順を繰り返す。

$$|z_{ij}(3) - s_{ij}| < \epsilon \quad (7)$$

$$i=1, \dots, n(2), j=1, \dots, m$$

が成り立つまで修正を繰り返す。但し ϵ は、収束を判定するための小さな正の数である。

このようにしてニューラルネットの重みを決定した後、未学習データに対するネットワークの出力を調べることにによりパターン認識が可能となる。

この方式では、入出力パターンに基づいた学習によりパターン認識ネットワークを構築できるため、限定的アルゴリズムを作る必要がないという大きな利点がある。

予備、推定等によりニューラルネットを用いる場合は、ニューラルネット出力が驚異値でなく異常値を取るだけで本質的な差異はない。

このようなニューラルネットの構成例に多層ニューラルネットの構成のうちとりわけ中間層ニューロン数を最適化する手法として従来の装置は、電子情報通信学会誌報告NCC85-104、P85~90における「海浜機能を有するバックプロパゲーション」に記載のように、中間層ユニットを学習時に動的に追加、削除することにより、その最適化を図っていた。

さらにJ・C・N・B・O・W・A・S・H・D・C、1973頁~1974頁における『Analysis of the Hidden Units of Back-Propagation Model by Singular Value Decomposition(SVD)』に記載のように、入力層と中間層の間のシナプスの重みを行列化し、この行列のSANKの値に着目して中間層ニューロン数を決定する方法が知られている。

【発明が解決しようとする課題】

またデータを追加して再度学習するという方法しかなく識別あるいは予備等の精度を上げるために試行錯誤になるという問題があった。また逆伝達法は、教師データを一個ずつ逐次的に処理するために学習が極めて遅いという問題があった。

本発明の目的は、与えられた条件に對して最適なニューラルネットを構成する手法を提供することにある。与えられた条件とは、(イ)ニューラルネットの規模の最適化(例えば、入力層のニューロン数、中間層のニューロン数、入力層と中間層のニューロン数の種を最小化するなどがある。)、

(ロ)学習の精度の指定(ハ)学習時間の指定

(ニ)教師データ以外の入力データに対する誤動作の最小化等ニューラルネットを構築する際に指定する条件をいう。本発明の他の目的は、学習によって得られたニューラルネットワークで未学習データに誤差あるいは大きな予測誤差が生じたときに、重みをチューニングする。あるいはネットワークを再構築することによりこれらを回避する手段を提供することにある。本発明の他のもつ

ては、記憶装置のうちの前者については、ニューロンを削除するかどうか(本文中では不良ユニットかどうか)の判断値に対しては要求されておらず、最も不良なものを残すか削除するかは適合には、その最適学習を必要とするため、従来の試行錯誤的シミュレーションと変わらない演算量が必要とする。またこの操作は打切る原理について記載されていないため、最も構成の狀態からさらに削除した場合には、ネットワークが収束しなくなることが問題となる。

また、後者の方式では、条件として中間層ニューロン数は、入力層ニューロン数以下の値となるため、中間層で情報が伝達されるタイプのニューラルネットにしか適用できないことが大きな問題となる。

また、入力層のニューロン数やその内容に關して、有効な最適化手法は知られていない。

また、一旦学習したネットワークでパターン識別あるいは予備等を行なうとき誤差あるいは大きな予測誤差が生じておいておき、その誤

1つの目的は、最適な学習方式を提供することにある。

【課題を解決するための手段】

本発明は、(イ)与えられた条件に對するニューラルネットの構築方法、(ロ)ニューラルネットの重みチューニング方法、(ハ)ニューラルネット再構築方法、(ニ)学習の最適化手法、などに特徴を有するものであり、これらの独立した手段、方法のみならず、種々の組合せにも多大の効果があつた。

以下問題を解決するための手段の一例を概念的に説明する。

(イ)与えられた条件に對するニューラルネットの構築方法

規模最適化するという過程のちでパターン認識用ニューラルネットを構築する方法について説明を行なうが予備等の問題と明確に適用が可能である。パターン認識をニューラルネットで行なう場合は、教師データに對するニューラルネットの出力は1あるいは0であり、シグモイド函数の

飽和特性が極めて重要な意味を持つ。ニューラルネットの出力（ニューラルネットの中間層又は出力層のニューロンの出力）1, 0に対応する出力ニューロンへの入力値は、 $+\infty$, $-\infty$ に対応するため、1, 0を各々 x_{i+1} , y として、学習の打ち切りを(7)式で行なうとすると、(7)式は、

$$\begin{aligned} x_{i+1} &= 1-x_i \text{ のとき} \\ 1 \geq Z_{i+1}(3) &\geq 1-2x_i \end{aligned} \quad (8)$$

$$\begin{aligned} x_{i+1} &= x_i \text{ のとき} \\ 2x_i &\geq Z_{i+1}(3) \geq 0 \end{aligned} \quad (9)$$

となる。これを出力ニューロンへの入力で考えたと、図4図に示す如く、

$$\begin{aligned} x_{i+1} &= 1-x_i \text{ のとき} \\ \infty > x_{i+1}(3) &\geq a \end{aligned} \quad (10)$$

$$\begin{aligned} x_{i+1} &= x_i \text{ のとき} \\ -a \geq x_{i+1}(3) &\geq 2-\infty \end{aligned} \quad (11)$$

得し

$$u = -T \log \{ (1/(1-2x_i)-1) = T \log (1/2x_i-1) \}$$

即ち出力側の有有限な区間が入力側では半無限区間に対応することになる。これにより(6)式の

$$x_i(i) < 0 \text{ あるいは } Z_i(i) < 1/2 \quad (14)$$

のとき超平面の負の側にあるということにする。またあるパターンは、そのパターンに属する全ての教師データが k 個の超平面の同じ側にあり、他のパターンは k 個の超平面で単一分離可能と呼ぶ。またあるパターンの教師データが単一分離可能な集合に分割されるときそのパターンは分離可能と呼ぶ。これら分離可能な超平面を以下分離超平面という。

第5図の平面上の3つのパターンの分離を考える。3つの平面 P_1 , P_2 , P_3 の矢印は、平面の正の側を示すとし、平面上の各点は教師データを示すとする。パターンIの全ての教師データは P_1 , P_2 の正の側にあり他の教師データは存在しないので、パターンIは平面 P_1 , P_2 で単一分離可能である。同様にパターンIVは平面 P_1 , P_2 , P_3 で単一分離可能である。また、パターンIIは単一分離可能な部分集合からなるから分離可能である。

以上のことから次のことを示すことができる。

最小化が、中間層と出力層の偏りの集約の決定に関しては、不等式を解くことで求まらうことが分かる。ここでもう少し一般化すれば、0に対応する出力ニューロンの値は $1-x_i(i)$, $x_i(i) \geq 0$ としたとき $x_i(i)$ の値が求まればよい。従って $x_i(i) = 0$ としても $x_i(i) > 0$ とすれば1と近似しことが出来る。以下では $x_i(i) = 0$ としても話を進めるが、 $x_i(i) > 0$ としても同じことが成り立つ。

ニューラルネットの意味は、超平面を決定する方程式の係数と解釈できる。(11)式で $x_{i+1}(3) = 0$ とすると

$$w_{i+1}(3) = 1/2 (x_i(i) - 1) = 0 \quad (17)$$

は、 $x_i(i) = 1$ 次元空間の超平面を意味し、バイアス項の重み $w_{i+1}(3)$, $x_i(i) = 1$ の値を定めることは、超平面を平行移動することに対応する。(11)式より(12)式を満足する $x_{i+1}(1)$ に対応する $Z_i(i)$ の値は $1/2$ となる。ここで $n(i-1)$ 次元の点 $\{Z_i(i-1), \dots, Z_i(n(i-1)-1)\}$ は、 $x_i(i) > 0$ あるいは $Z_i(i) > 1/2$ (13)のとき超平面の正の側にあり、

$n(i-1)$ 次元データを $n(i-1)$ 個のパターンで分離することを考える。 $n(i-1)$ 次元空間に $n(i-1)$ 個の超平面が存在し、 $n(i-1)$ 個のパターン全てが $n(i-1)$ 個の超平面の部分集合で単一分離可能となるとき、入力 $n(i-1)$ 個、中間層ニューロン $n(i-2)$ 個、出力 $n(i-3)$ 個の3層のニューラルネットではパターン分離が可能である。

これは次のようにして分かる。 $n(i-2)$ 個の超平面を

$$w_j(1)Z_i(1) = 0, \quad j=1, \dots, n(i-2) \quad (15)$$

とする。ここで

$$\begin{aligned} Z_i(2) &= 1/(1+\exp(-x_i(2)/T)), \\ Z_i(2) &= w_j(1)Z_i(1), \quad j=1, \dots, n(i-2) \end{aligned} \quad (16)$$

として、ニューラルネットの第1、第2層に対応するようにする。そうすると仮定により、教師データに対応する $Z_i(2)$ は、

$$Z_i(2) > 1/2 \text{ あるいは } Z_i(2) < 1/2 \quad (17)$$

のいずれかになる。

従って $w_j(1)$ に正の定数を与えると、教師デ

ータに対応する $z_i(2)$ を

$$z_i(2) = 1 \text{ あるいは } z_i(2) = 0 \quad \cdots(18)$$

のどちらかにすることができ、

次に出力と中間層ニューロンの間の重みを求める、出力ニューロンの入力 $x_i(3)$ を

$$x_i(3) = w_{ij}(2)z_j(2) \quad i = 1, \dots, n(3) \quad \cdots(19)$$

で与えられるとする。 $w_{ij}(2)$ は1層目のパターンに対して $x_i(3)$ が1- α でそれ以外のパターンに対しては、 α となるように決めればよい。そのためには

$$w_{ij}(2)z_j(2) \geq \alpha \quad \text{パターンI} \quad \cdots(20)$$

$$w_{ij}(2)z_j(2) \leq -\alpha \quad \text{パターンI以外のパターン} \quad \cdots(21)$$

とすればよい。

第1図のパターンIのようにパターンIが $n(2)$ 個より少ない層平面で分離されるときは、分離に失敗していない平面に対応する重みを0とすればよいので、パターンIは $n(2)$ 個の平面で分離されると仮定する。この仮定によりパターンIに対する $z_i(2)$ 、 \dots 、 $z_{n(2)}(2)$ の出力は一意

ばよい。

以上の説明より、もしパターンIが分離可能であるならば、3層目でパターンIの各々の分離領域を分離し、4層目でそれらを合成することにより4層のニューラルネットワークで分離が可能となることが分かる。

なお何パターンが層平面によりいくつかの領域に分離されるときも、それらの領域が異なるパターンに対応する領域と1つの層平面で分離できるときは3層で合成することができる。

またここで証明を簡略化するために、中間層の出力を1と0としたが、実際は0の必要がない。

上記の手順を行なうと第5図の平面上の点の分離を行なうニューラルネットワークは次のようになる。入力と中間層の重みは、図の直線を表現する方程式の係数に設定する。このとき重みの符号は図の矢印の方向が正の側になるようにとる。重みに正の値をかけることにより中間層の出力が1、0をとるようにすると各パターンに対する入力は次のようになる。

に決まる。ここで、

$$z_j(2), \dots, z_{n(2)}(2) = 1, 0, \dots, 0 \quad \text{パターンI} \quad \cdots(22)$$

とする、最も最初の、最も深い層で重みが与えられるとする。

さらに

$$w_{ij}(2) = 2\alpha \quad j = 1, \dots, s \quad \cdots(23)$$

$$w_{ij}(2) = -2\alpha \quad j = s+1, \dots, n(2) \quad \cdots(24)$$

とすると、(23)、(24)式は各々次のようになる。

$$w_{ij}(2)z_j(2) \geq 2\alpha \quad \text{パターンI} \quad \cdots(25)$$

$$-\alpha \leq 2\alpha \sum_{j=s+1}^{n(2)} z_j(2) + 2\alpha \sum_{j=1}^{s(2)} z_j(2) \leq w_{ij}(2)z_j(2) \quad \cdots(26)$$

$$\text{パターンI: 1 以下} \quad \cdots(27)$$

パターンIは単一分離可能であるから、 $z_i(2) = 0$ が $j = 1, \dots, s$ のどれかの j で成りするか、 $z_i(2) = 1$ が $j = s+1, \dots, n(2)$ のどれかの j で成立する、従って(23)、(24)式を満たす $w_{ij}(2)$ を定めることができる。それには例えば $w_{ij}(2) = \alpha(i-2j)$ とす。

出 力	パターンI	パターンII	パターンIII
$z_1(2)$	1	0	0
$z_2(2)$	1	1	0
$z_3(2)$	1	0	1

パターンIで $z_i(2)$ が1と0をとるが、 $z_i(2)$ と $z_j(2)$ がどちらの場合も1であるから $z_i(2)$ はパターンIに属している。従ってパターンIは直線 P_1 、 P_2 により層平面で分離可能である。同様にパターンIIは直線 P_3 、 P_4 、 P_5 で単一に分離可能である。これに於いてパターンIIは分離可能である。従って第5図のニューラルネットワークが構成される。図において10100〜10112は入力ニューロン、10113〜10116、10118、10119は中間層ニューロン、10117、10120、10121は出力ニューロンである。10113、10114、10115は各々直線 P_1 、 P_2 、 P_3 に対応している。また10117、10121、10120は各々パターンI、II、IIIに対応している。パターンIは、直線 P_1 、 P_2 により単一分離可

能であるから1011と1017とはつながっていない。パターン1は、2つの単一分割可能な領域を合成することになるので4層ネットワークで構成される。4層の重みは

入 力	中 間 層	出 力
1	0	1
0	1	1
0	0	0

となるように重みを決めればよいので

$$w_{11} + w_{12} \geq \alpha$$

$$w_{11} + w_{21} \geq \alpha$$

$$w_{22} \leq -\alpha$$

が成立するようにとればよいので

$$w_{11} = -\alpha$$

とすれば、

$$w_{12} + w_{21} = 2\alpha$$

とすればよい。

ここで1011、1019どちらの出力も1となることはないがそのときも1021の出力は1

き入力と中間層の重みは、各パターンを分離するように設定されていけばよく、教師データに対する中間層出力が1、0となる必要はない。各パターンを分離とは、各パターンの教師データの少なくとも2つ以上教師データを含む部分集合に対して、中間層出力2.(2)が

$$Z_i(2) > 1/2 \text{ あるいは } Z_i(2) < 1/2 \quad \dots(27)$$

のどちらかになっていることを言う。

未学習データ $x_i(1)$ 、 $i=1, \dots, n(1)$ をニューラルネットに入力して、誤認識が生じたとし、 $x_i(1)$ に対応する中間層出力及び出力を $z_i(2)$ 、 $z_i(2)$ 、 $i=1, \dots, n(2)$ とする。このとき、未学習データがパターン k に属するとき、パターン k に対応する教師データに対応する中間層の入力あるいは出力と比較し、未学習データが教師データが存在しない超平面の側に存在する中間層ニューロンを提出する。このニューロンが誤認識を生じる範囲となっていることが分かる。

次にその中間層ニューロンの重みを調整し、未

となる。

以上の手順によればネットワーク構造を最適化できる。また分離平面を教師データの任意の境界にとれるため誤認識に強いネットワークとすることができ

る。誤差を最適化するという操作を達成する別の手段として、入力信号セットと出力信号セットからなる教師情報（ニューラルネットワークの入力と出力に関する既知の対応関係）の内容を基に、ニューラルネットワークの各シナプスの重みを決定する同定手順を踏えたニューラルネットワーク構築手順に、これらと情報交換しつつ進捗するニューラルネットワーク最適設計手順を踏えたものである。

また該ニューラルネットワーク最適設計手段に、入力信号最適化手段と中間層ニューロン数最適化手段を備えたものである。

(ロ)ニューラルネットワークの重みのチューニング方法

(イ)の最初の方法でパターン認識を行なうネットワークが構成されているとする。但しこのと

学習データが、同一パターンの学習データとその平面に対して同一の側にあるようにする。このとき他のパターンに属する教師データのその平面に対する位置関係を覚えてはならない。この誤差の仕方としては例えば、超平面を平行移動即ちバイアス項を最適化せればよい。最適化を行なう場合も、同様の方法により重みのチューニングが可能である。

(ハ)ニューラルネットワーク構築方法

上記目的を達成するために、ニューラルネットワークの性能（制約性能、認識率、汎化能力、予測精度等）を評価する手段と、性能が低下したときに教師データの内容を更新する手段と、この該ニューラルネットワーク最適設計手段に再度起動をかける再構築指令発生手段よりなるニューラルネットワーク構築手段を備えたものである。

(ニ)学習の高速化方法

(イ)の考え方を利用すれば任意のパターン認識の学習法も高速化ができる。ここで $x_i(1)$ 、

$z_i(2)$ の教師データを用いて学習がある段階に進ん

段階で、

- ・ $s_{i,j}(2) > 1/2 + \epsilon_1$ あるいは $s_{i,j}(2) > \epsilon_1 \dots (28)$
- ・ $s_{i,j} = 0$ に対して

$s_{i,j}(3) < 1/2 - \epsilon_1$ あるいは $s_{i,j}(3) < \epsilon_2 \dots (29)$
 が全ての $i = 1, \dots, n(3)$, $j = 1, \dots, m$ に対して成立するか調べる。ここで ϵ_1, ϵ_2 は、学習の段階を指定する正の小さな定数である。もし成立すれば学習を終了し、

$$M_i = \min_{k=1, \dots, n} \{x_{i,j}(3)\} \dots (30)$$

を求める。ここで $M_i < \alpha$ のとき $w_{i,j}(2)$ を次のように修正する。

$$w_{i,j}(2) = (\alpha/M_i)w_{i,j}(2), k=1, \dots, n(2)+1 \dots (31)$$

$M_i \geq \alpha$ のときは $w_{i,j}(2)$ を修正する必要はない。

ここで (28) あるいは (29) が成立すれば、パターンは既に分離されているから、(30)、(31)の手順で重みを定数値にすることによりネットワークの出力が 1, 0 になるように調整できる。

なお $w_{i,j}(2)$ だけの調整だけでなく、 $w_{i,j}(1)$

を、他のニューロンの出力で重複している成分と重複していない成分に分離し、これらの比率から最適ニューロン群を決定する。

- (ロ) 入力と中間層の重みをパターンを分離する超平面に対処させることにより、誤認識が生じたときに重みを調整することにより誤認識を解消することができる。

- (ハ) ニューラルネットワーク再構築方法

ニューラルネットワークの性能を評価する手段は、教師データに含まれないデータに関し、対応するニューラルネットワークの出力が、希望の出力データとなっているかどうかを判定する。そして希望の出力データが得られていないとき、性能が低下したことを判定する。このとき教師データの内容を更新する手段は、希望の出力データが得られなかった入力データと、これに対応する希望の出力データの組合せを教師データに追加する。再構築指令発生手段は、前に述べたニューラルネットワーク最適設計手段を繰り返し、ニューロン数の最小化、シナプスの重みの再構築を

を分離超平面に対処し、さらに調整した重み $w_{i,j}(2)$ を調整したが、おおよそ、強いコストをすることができ、

【作用】

- (イ) 学習の段階を (5)、(6) 式あるいは (15)、(17) 式とすることにより、中間層と出力層の重みを不等式を解くことにより求めることが可能となる。また入力層と中間層の重みを、パターンを分離する超平面に対処させることにより、パターン分離を行うニューロンのネットワーク層あるいは 4 層で構成できる。

また成績を最適化する別の方法で入力層最適化手段は、前記記憶手段の情報をあひ、実施例に詳述する手段で、出力の決定に貢献している無意味な入力と、他の入力の線形和で表わされる冗余な入力を排除する。

中間層：ニューロン数最適化手段は、計算が許した範囲のニューロン数を選択し、入力、このときの各中間層ニューロンの出力、出力を分析する。具体的には、各ニューロンの出力

を行う。

- (ニ) 全ての教師データが、パターン毎に分離された段階で学習を終らせることにより、学習の最適化を図ることができる。

【実施例】

以下、本発明の一実施例を第 1 図を用いて説明する。図において、101 はニューラルネットワーク構築装置、102 はニューラルネットワーク最適設計手段である。103 は記憶手段、104 はニューラルネットワーク系の線形和に基づいて入力信号に対する出力信号を算出する手段である。入力に対する望ましい出力の組合せ（教師データ）は、前述する第 1 図に示す記憶内容の 105 に記憶されており、ニューラルネットワーク最適設計手段 102 は指定された入力と教師データとにより条件を満たすニューラルネットワークを構築する。

第 7 図に、ニューラルネットワーク最適設計手段 102 の処理フローを示す。

ステップ 107 では、ニューラルネットワークを最初

ら構築する場合はステップ11へ、そうでないときはステップ12に進む。

ステップ11では、ニューラルネットワークを構築し終了する。

ステップ112では、誤りが生じたデータを教師データを用いてニューラルネットワークの重みをチューニングして誤りを軽減して処理を終了する。ネットワーク構築の最小化及び誤認識に強いことを条件にパターン認識用ネットワークを構築するステップ11の手順を図8図に示す。

ステップ111において、教師データ $(x_i(1))$, $x_i(1) = 1, \dots, n(1)$, $j = 1, \dots, n(3)$, $k = 1, \dots, m$ を用いて $n(3)$ 層のパターンに分離する平面を決定し、それによりニューラルネットワークの中間層数 $n(2)$ 及び入力と中間層部の重み $W_{ij}(1)$, $j = 1, \dots, n(2)$, $j = 1, \dots, n(1)$ を決める。

次にステップ112において、 $n(3)$ 層の各パターンに対して、(20), (21)式が成立するように重み $W_{ij}(2)$, $j = 1, \dots, n(3)$, $j = 1, \dots,$

力(あるいは出力)とを比較し、教師データが存在しない超平面の側にある中間層ニューロンを検出する。

次にステップ1122において、検出された中間層ニューロンに対して誤認識を生じたデータが同一パターン教師データと同じ側になるように重みを調整する。このときその超平面により分離されている教師データの位置関係を変えない範囲で調整する。それが終わったら第8図のステップ112と同じ手順で出力層の重みを調整する。

最も簡単な重みの調整法は、バイアス項を加えて、超平面を平行移動することにより行なうことができるが、第8図のステップ111と同じ方法を用いてもよい。

第7図のステップ11の別の実施例を図10図に示す。

まず、ステップ113において、教師データ $(x_i(1))$, $x_i(1) = 1, \dots, n(1)$ を用い、伝伝法、その他の手法でニューラルネットワークの重みを修正する。

次にステップ114において、(18), (20)式が

$n(2)$ を決める。

ここで111のステップにおける分離平面の決定は、例えば、「パターン認識に学習機械」朝倉豪(昭和45年)の8頁、41頁の手順で行なうことができる。

なお112のステップ1121中間層の重みを1、1になるように調整し、(20), (21)式に従って重みを決定、また、分離可能な平面は、5層あるいは5層で余裕がある、1、0になるように調整していき、(18), (20)式の不等式を解けば求めることができる。なお112のステップで分離に失敗していない中間層ニューロンの出力は、対応する出力ニューロンには入力しないようにする。

第7図のステップ12のパラメータチューニングのステップは、単自習のようになる。即ち、先ずステップ121において、誤認識を生じた入力データ $x_i(1)$, $i = 1, \dots, n(1)$ の中間層の出力 $x_i(2)$ (あるいは出力 $x_i(2)$) とそのデータに対応するパターン j の教師データの中間層の入

力(あるいは出力)とを比較して、ステップ112へ進む。そうでなければ、ステップ113へ進む。

ステップ113において、入力側の重みが分離平面となるように重みをチューニングする。具体的には、例えばバイアス項を加えて分離能力を平行移動することにより行なう。

次にステップ114において、入力側の調整に従い、出力側の重みを、第8図のステップ112と同じ手順で修正する。このときもパターン分離に失敗していない中間層ニューロンと出力ニューロンとは動かないことにする。

なお上の手順でステップ115を行なう必要はなく、そのときは、(30), (31)式の手順で $W_{ij}(1)$ を修正すればよい。

第8図において、パターン i をパターン m とパターン n の2つに分けて単一分離可能として、第10図の113, 114のステップを実行したときの平面の学習結果を図11図に示す。このとき113のステップの学習は、入力データを1層目で層毎に重みを決める方式とした。このとき

11 図において、各層、P2、P3 のバイアス項を調整して平行移動させると、第 1 図のようになるパターンを分離でき、11a、11b のステップを実現できる。

このようにするときに、より誤認識に強いニューラルネットを構築することができる。

以下、本発明の他の実施例を図に就いて詳細に説明する。まず第 1 図により装置全体の構成を説明する。本実施例でニューラルネット構築装置 101 は、入力信号に後述する所定の演算を施した後出力するニューラルネット演算手段 102、入力信号に対するニューラルネット演算手段 102 の操作として望ましい入力と出力の組合せ（以下教師信号）を供給しておく記憶手段 103 と信号の交換を行う。ニューラルネット構築装置 101 は記憶手段 103 に格納されている教師信号を基に、ニューラルネット演算実行手段 102 の演算定数を決定する判定手段 104、記憶手段 103 の内容および判定手段 104 の学習結果を基に、ニューラルネット演算手段 102 の最適化構成を

決定するニューラルネット最適化手段 105 から構成される。またニューラルネット構築装置 101 には、ニューラルネット演算手段 102 へ入力される入力信号の内容を代表する入力信号最適化手段 106 と、107 の内部構造である中間層のニューロン間の最適化値を決定する中間層ニューロン最適化手段 107 からなる。以下各手段の機能を順次詳細に説明する。

ニューラルネット演算手段 102 は第 1 図に示すように、入力演算手段 201、中間演算手段 202、出力演算手段 203 により構成される。入力演算手段には、ニューラルネット演算に必要な入力信号（観測応答の信号には観測対象からの帰属信号、認識応答の場合は結果が望ましい結果等）が入力される。またここで演算手段 201 からは演算結果として、観測両方と認識結果に対応した信号が出力される。各演算手段は算術的演算単位 204 からなる。演算単位 204 を結合するアーク 205 は演算単位間の信号の流れを表わしており、図に示すように、前後した演算手段に

含まれる演算単位と結合される。演算単位 204 は入力アークにより結ばれている他の演算単位の出力値を入力データとして取込み、後述する演算を行い、その結果を出力アークにより結ばれている他の演算単位へ出力する。第 1 図は 0～9 の数字を認識するシステムにニューラルネット構築装置 101 を適用した例を示している。この場合入力演算手段 201 には数字を判別するための特徴量として、図形に含まれる穴の数が各ニューロンに入力される。入力情報としてはこの他に、図形を適用数に分割し、各領域の情報（商業があるかないか等）を、領域に対応したニューロンに入力する方法も考えられる。また出力演算手段 203 の各ニューロンは、例えば 0～9 の各数字に対応したものが用いられる。各出力ニューロンは、割り付けられた数字に該当した信号が入力されたときアクティブとなり、これらの結果が出力される。

第 1 図に演算単位 204 が実行する演算の内容を中間演算手段 202 に含まれる演算単位の動

作を例にして示す。他の演算単位からの入力値 $X_1 \sim X_n$ を取込んだ後、各入力値に対応した重み W_i を乗じ、その結果を加算し、すなわち

$$u = \sum_{i=1}^n W_i \cdot X_i \quad (32)$$

で与えられる u を定められた関数 f で変換し、出力値 y を決定する。関数 f の形は様々考えられるが、一般に広く用いられる例としてはシグモイド関数と呼ばれる。この式の右端形が関数がある。

$$f(u) = \frac{1}{1 + e^{-f(u)}} \quad (33)$$

（ T 、 u は定数）

第 1 図は中間演算手段 202 中に属する演算単位について示したが、入力演算手段 201 に属する演算単位の場合、入力は第 1 図から判明のように唯一となる。したがって第 1 図で $n=1$ の場合と考えればよい。また出力演算手段 203 に属する演算単位の場合には、逆に出力が唯一とな

る。ニューラルネット演算手段 102 の構成としては、中間演算手段を 2 つ以上設けた多段構成や、入力演算手段 201 の出力に直接出力演算手段 302 を結合した構成を考慮される。また入力演算手段 201 の関数 5 による変換を省略することも考えられる。

記憶手段 105 は、ニューラルネット演算手段 102 における入力信号セットと出力信号セットの望ましい組合せをデータの対として、たとえば第 14 図に示す形態で記憶する。本実施例で入力信号セットは前述した図形情報により構成され、出力信号セットは 0〜9 に対応しており、例えば図のように読取る数字を 1、他を 0 で与える。これらは固定手段 104 における固定用のデータとして用いられる。詳しくは後述するが記憶手段 105 には、この他に固定結果の検証用データとして、第 15 図の形態で入力信号セットと出力信号セットの対を格納しておくことも考えられる。

固定手段 104 は、記憶手段 105 に蓄えられている入力信号セットと出力信号セットの組合せ

から、学習によりそれらの関係を設定する。前述は図式に示したニューロン内シナプス重み W 、の更新により行われ、最終的な固定結果によりニューロンの内部状態 U 、 V 、が転送されるシナプスの重み W が決定される。第 16 図の固定手段 104 の構成を示す。本実施例では、種々の学習により固定を行う例を示す。ニューラルネット演算系演算手段 500 に含まれ、ニューラルネット演算手段 102 の構成に対応した、入力演算手段 501、中間演算手段 502、出力演算手段 503 に加え、記憶手段 105 から読込んだ図形信号である入力信号セットと出力信号セットそれぞれ受信する機能、出力演算手段 503 の出力と出力信号セットとの差分を基に各ニューロンのシナプスの重み W 、を修正する機能を備えている。以下学習動作の代表例であるバックプロパゲーション法について説明する。

まず記憶手段 105 に蓄えられている入力信号セットと出力信号セットの対を一つ抽出し、入力信号を入力演算手段 501 の対応したニューロン

決定する。

本発明で新たに導入された、シナプス最適化手段 107 は、学習手段 104 に格納されている信号を分析して入力信号セットに含まれる信号の内容を認識して入力図形最適化手段 106 と、学習手段 104 の学習結果として構築されたニューラルネット演算系演算手段 500 の入力信号セットをあたかも入力したときの中間演算手段の各ニューロンの出力、即ちして中間層ニューロンの最適値を決定する中間層ニューロン最適化手段 107 を備えている。

第 17 図のニューラルネット系最適化手段 105 の機能を示すアルゴリズムと、固定手段 104 との間の情報交換方式を示す。T、U、V、が人工信号最適化手段 106 の機能で、が中間層ニューロン数最適化手段 107 の機能であり、本実施例では、入力信号最適化手段 106 の出力は、まず、記憶手段 105 の出力信号と入力信号

を入力する。このとき各演算手段の前送した演算の後、出力演算手段 503 から出力される各ニューロンの値を、対応した出力信号セットの値と比較し、不一致の差分を算出する。そしてバックプロパゲーションの名で知られるアルゴリズムに従い、差分がなくなるように各演算手段 501、502、503 に属する演算手段の重み W 、を変更していく。従ってアルゴリズムの詳細は、たとえば『ニューラルコンピュータ』（東京電機大学出版部、会第 1 巻）の p.110〜113 に述べられている。総てのニューロンの重み変更が終わると、固定手段 104 は記憶手段 105 から別の信号の対を同様に抽出し、同じ手順で重みの変更を行う。これを記憶手段 105 に蓄えられている総ての信号の対について行う。この動作を、前述した不一致の差分が許容範囲以下になるまで繰り返す。このようにして決定された各演算手段の重みを、(1) はアーク番号、(2) はニューロン番号とする。固定手段 104 は W_{ij} をニューラルネット演算手段 102 の各シナプスに、(3) の各シナプスの重みを供

等セット)を返込む。T₁とT₂ではこれらを用いて出力に貢献しない入力と冗長な入力を指摘する。

出力に貢献しない入力判定方法として本実施例では、教師データの各入力ニューロンと出力ニューロンの値に着目する方法を示す。まず1つずつの入力ニューロンと出力ニューロンを抽出し、これに対応した教師信号の値をX_i, T_i (i=1, 2, ..., N; Nは教師信号数)とする。入力値のフルスケールを減当数N_Tに分割し、分配された各エリア(1, ..., N_T)に属するX_iに対応したT_iの値を求める。ここで例えはT_iの平均値であるT_{ave}を用いて、T_i≧T_{ave}である場合とT_i<T_{ave}である場合のX_iの個数をカウントすることにより、第18図(a)の2つのヒストグラムが得られる。

各エリアを1, ..., k, ..., N_Tとし、T_i≧T_{ave}のX_iの個数をU^k, T_i<T_{ave}のX_iの個数をU^{k*}とする。次に2つのヒストグラムについて各エリア毎にU^kとU^{k*}の小さい方の値で

1, ..., pは入力信号セットのデータ番号, j=1, ..., qは出力信号セットのデータ番号)とすると、各入力信号と出力信号のD_{ij}の値を用いて、第20図のテーブルが構築できる。このとき適当な閾値(D_{ij})_{th}を設定し、各入力信号について(D_{ij})_{th}より小さいD_{ij}の値を2つ以上有していないものを、出力に貢献しない入力として指摘する。

次にT_iの動作を説明する。冗長な入力を検出する手法として本実施例では、後の入力信号の線形和と表わされる割合を指標とした場合を示す。この割合を与える統計量として、本実施例では寄与率R²を用いた。R²は以下の式で表わされる。

$$R^2 = 1 - (S_{yy} / S_{yy}) \quad (34)$$

$$S_{yy} = \sum_{i=1}^N (X_{ii} - \bar{X}_{ii})^2 \quad (35)$$

$$S_{yy} = \sum_{i=1}^N (X_{ii} - \bar{X}_{ii})^2 \quad (36)$$

$$\bar{X}_{ii} = (1/N) \cdot \sum_{i=1}^N X_{ii} \quad (37)$$

ある区間X₁(区間X₂...)を平均、第18図(b)のヒストグラムを求め、このヒストグラムを本論ではANDヒストグラムと呼ぶ。ここでANDヒストグラムには第19図的2つのパターンが存在する。(a)の場合、抽出した入力値は抽出した出力値をそれ以外の出力値と完全に分離する能力を備えていることを示している。また(b)の場合、抽出した入力値は、抽出しき出力値を他の出力値とともに、それ以外の出力値と混同する能力を備えている。(c)の場合には、抽出した入力値は抽出した出力と無関係である。結局、抽出した入力値が抽出した出力値を予測する能力がないのは、(c)の場合であり、それはANDヒストグラムの要素数が多く、しかもそれらが入力値のスケール全体に分散している場合である。そこで例えは要素数と要素の分散をかけた値を指標とできる。この値が大きいときはANDヒストグラムの形状は第19図(c)となり、予測能力が小さいと判定される。この値をD_{ij}と表す。

但し、

X_iはi番目の入力信号のi番目の教師信号の値, i=1, ..., P, j=1, ..., N
S_{yy}は残差平方和
S_{yy}は平方和
X_{ii}はX_iをX₁, ..., X_P, ..., X_N, ..., X_Nの総称式で近似したときのX_iに対応した詳細値
T_iはX_{ii}の平均

各入力信号についてR²の値を求めたときR²が最大(入力信号が最も冗長な入力として指摘される)統計量としてはR²の値を残差平方和の値や標準偏差とされる。

入力信号の形態によりニューラルネットワーク構築時10.2の性能を取らせたい場合、10.2の性能を確認しながら入力信号を削除する方法を示す。まずT_iで出力に貢献しない入力がいくつか指摘されると、データベースによりこれらの番号を同定手段10.4へ転送する。次にT_iにおいて、T_iで指摘された信号以外の入力信号の中で、

最も小さい入力信号の番号をデータパス2により、固定手段104に伝える。S1では今回転送された信号番号とT₁で転送された信号番号を除いた入力信号セットと、出力信号セットを候補信号の入力信号セットとして学習を行う。この結果構築されたネットワークを、記憶手段105から取込んだ所使用の入力信号セットと出力信号セットを用いて評価する。本実施例では出力信号セットと、入力信号セットを入力したときのニューラルネットワーク演算結果手段500の出力を比較した結果を、認識率として評価の指標にすればよい。R₁で性能の低下が学習範囲内であることを確認したうえで、S3でこの入力を除くことを決定する。この後データパス5で次の入力信号をニューラルネットワーク最善設計手段105に要求する。105は前回転送した入力信号をさらに除いた入力信号セットの組合せで同様に各入力信号のR₁を算出し、最もR₁が大きい入力信号の番号をデータパス2により固定手段104に送る。以下、SへS₃の演算が繰り返される。S₃で性能が低下

した場合には、S4で前回までに除いた入力信号を削除可能と判定する。

また、第1で図1に示す入力信号最適化手段70の他の実施例を第2に図に示す。この手法は、次のような点に基づいていく。まず、ニューラルネットは、第1に示すような学習データ、入力信号セットと出力信号セットの組合せからパターンと認識の出力を学習している。そのとき、輸入された入力信号セット(X₁, X₂, ..., X_n)、(i=1, ..., n)のみに学習が入力(X₁, X₂, ..., X_n), (1 ≤ i, j < n)が含まれていない場合は、それがパターン認識の出力に与えない影響、すなわち入力の変動に対する出力の感度が低くなると考えられる。そこで、第2に図の実施例では、学習済みのニューラルネットの入力の変動と出力の関係を表わす感度特性に着目し、その特性を解析することにより低感度入力を検出し、それを削除することで最適な入力を選択する。

本実施例に基づく入力信号最適化手段100には、まずT₁で記憶手段105より第1の図に示す如

習データ（入力信号セットと出力信号セットの組合せ）を読み、これをカテゴリ毎に分群する。カテゴリ毎に分群する方法としては、第15例に示す如く学習データの中から出力信号セット(T₁, T₂, ..., T_n)が同じものをグループ化して、それを1つのカテゴリとする方法を用いればよい。すなわち、例えば番号1の出力信号セット(0, 0, 0, ..., 0, 0, 1, ...)と同じ出力信号セットを番号2〜Nの学習データから選択してグループ化して、それをカテゴリ1とする。次に、番号2の出力信号セット(0, 0, 1, 0, 0, 0, ..., 0, 0, 1)と同じ出力信号セットを番号3〜Nから選択してグループ化し、それをカテゴリ2とする。以下、この操作を繰り返して学習データをカテゴリ毎に分群する。T₁では、T₁で分類したカテゴリ毎に入力信号セット(X₁, X₂, ..., X_n)の中のX_i (i=1〜n)を変動させ、そのときのニューラルネットの出力を観測する。このとき、X_i以外の入力信号セットとしてはカテゴリの代表値を入力する。代表値としては、

下式に示すようにカテゴリ毎に分群した群数の(n(C_i)/個)の入力信号セットの平均値X_{mean} (i ≠ 1, j=1〜n)を用いるか、あるいは、平均値X_{mean}に最も近接した入力信号セットを用いることが考えられる。

$$X_{mean} = \frac{n(C_i)}{n} X_{input}(C_i)$$

ここでn(C_i)はカテゴリC_iの学習に用いられた入力信号セットの個数である。

また、T₁で観測するニューラルネットの出力は、カテゴリC_iを認識する出力ニューロンC_iとそれ以外の出力ニューロンである。そして、入力信号X_iを変動させた時の出力ニューロンC_iとそれ以外の出力ニューロン各々の出力を第2に図のようにグラフ化する。グラフ化は入力特性、すなわち感度特性を示す。例えば第2に図(a)のように出力ニューロンC_iの出力値が出力ニューロンC_i以外の出力ニューロンC_jの出力値と交差しない場合はその入力X_iはカテゴリC_iの認識に影響を与えない入力であるものと

評価する。一方、式(2)と同じように出力ニューロンC_iの出力値が、出力ニューロンの、取
 得の出力ニューロンの出力値と一致する場合はそ
 の入力X_iに、カテゴリーC_iの認識に影響を与え
 る入力であるためXと評価する。評価結果の○あ
 るいは×を、例えば図23例に示すように、カテ
 ゴリーを縦の欄に、入力信号セットを横の欄につ
 いた表の中に記入していく。カテゴリーC_iにつ
 いて、全ての入力信号を1つずつ変動させたとき
 の特性を調べて○、×を表に記入する。カテ
 ゴリーC_iが終了したら次に別のカテゴリーに対
 して同様に変動特性を調べて○、×を表に記入し、
 第23例の表(特性表)を完成させる。

最後に、第21図のT₁₂では、T₁₁で作成した
 感度特性表を入力信号X_i (i=1~p)につい
 て順方向に調べ、ほとんど全てのカテゴリーにつ
 いて○となっているX_iを抽出し、それを削除可
 能な入力信号として扱える。

削除可能と指定された入力信号の番号iを第
 17図のデータベース1あるいは2を介して同定手

段104へ転送される。

前述した入力信号最適化手順の同定手順の場
 合と同様に、T₁₁から転送された番号ある除い
 た入力信号セットと出力信号セットを学習データ
 として学習を行なう。この結果確認されるニュー
 ラルネットの認識率を評価し、入力信号を削除す
 る前の認識率に比べて認識率の低下がないことを
 確認したうえで、S_iでこの入力を除くことを決
 定する。認識率が低下した場合は、削除する前の
 入力信号セットに戻して終了する。この後データ
 バス3で次に削除可能な入力信号をニューラルネ
 ット系最適設計手段105に送る。ニューラル
 ネット系最適設計手段105は、削除可能な入
 力信号を除いた入力信号セットを用いて学習した
 ニューラルネットについて再び感度特性を求め、
 次に削除可能な入力信号があるかどうかを調べる。
 削除可能な入力信号があれば(記号○)を、な
 ければ中間層ニューロン最適化手段107に移
 る。

次に、T₁の中間層ニューロンの最適化決定の

方法を説明する。同定手段104

は、S_iで除かれなかった入力信号により構築さ
 れたニューラルネット最適化手段500に入力信
 号セットを次々に入力したときの、中間層計算
 手段502の各ニューロンの出力(Y₁, ..., Y_q)
 を、データベース4により、ニューラルネット系
 最適設計手段306に転送する。中間層ニューロン
 最適化手段107は、各入力信号セットに対応
 したY₁~Y_qの出力を統計処理し、その値から、
 最適なニューロン数を決定する。本実施例は各ニ
 ューロンの外部信号に対応した出力値の感度特性
 を計算の要素部分とし、これに相当するニューロン
 数を除くことで最適化する手段を示す。

図24例に本手法のアルゴリズムを示す。まず
 S_iでiを1にする。S_iで転送されたY₁~Y_q
 の値より、Y₁をY<sub>1,1}~Y_{1,n}}の総和で近似した
 値を \bar{Y}_1 とする。このとき</sub>

$$\bar{Y}_1 = b_0 + b_{1,1} \cdot Y_{1,1} + \dots + b_{1,n} \cdot Y_{1,n} \quad \dots (38)$$

近似式はよく知られた線形重回帰分析等により、
 容易に求められる。次にY₁がY_{1,1}~Y_{1,n}}の総和}

で記述できた割合として、Y₁と \bar{Y}_1 の相関係
 数の絶対値C₁を求め算出する。C₁は、次式で
 与えられる。

$$C_1 = |M_{1,1}| / \sqrt{S_{1,1} \cdot \bar{S}_{1,1}} \quad \dots (39)$$

$$M_{1,1} = \sum_{j=1}^N (Y_{1,j} - \bar{Y}_{1,j}) \cdot \left(\sum_{j=1}^N Y_{1,j} - N \bar{Y}_{1,j} \right) / N \quad \dots (40)$$

$$S_{1,1} = \sum_{j=1}^N Y_{1,j}^2 - \left(\sum_{j=1}^N Y_{1,j} \right)^2 / N \quad \dots (41)$$

$$\bar{S}_{1,1} = \sum_{j=1}^N \bar{Y}_{1,j}^2 - \left(\sum_{j=1}^N \bar{Y}_{1,j} \right)^2 / N \quad \dots (42)$$

但し N : 総データ数

Y<sub>1,1} : i番目の外部信号の入力信号セ
 ットを入力したときのi番目の中間
 層の出力</sub>

$\bar{Y}_{1,1}$: i番目の外部信号の入力信号セ
 ットを入力したとき、(38)式で与え
 られる値

C₁は0~1の値をとり、C₁=1のときY₁は
 Y_{1,1}~Y_{1,n}}の感度特性で完全に記述できたことを示}

している、逆に、 $m=0$ のとき、 Y_i は Y_1, \dots, Y_n の総てと全く無相関である。 S_i で1の値をインクリメントし、 S_i で1が中間演算手段502のニューロン数 m と一致しているか判定する、一致していないとき、 $S_i \leftarrow S_i$ の処理を繰返す、一致していれば、 S_i で、

$$SUM = m - (C_1 + C_2 + \dots + C_{n-1}) \quad (43)$$

を計算し、 S_i の値を最適なニューロン数とする、実際にはニューロン数は整数であるため、 S_i で値を整数化する、ニューロン数はデータバス6を通して判定手段104へ送られる。

本実施例では、各ニューロンの出力値の線形関係を定量化して抽出する手法として、統計量である寄与率と相関係数に着目したが、各ニューロンの出力値の分散等の他統計量に着目したアルゴリズムも考えられる。また統計量でなく、各シナプスに与えられている重み W_{ij} の値を評価して求めることも考えられる。さらに本実施例では、各ニューロンの出力の線形関係成分と非線形関係成分に着目

して行ったが、非線形関係を他の成分で評価することも考えられる。またニューラルネットワーク最適設計手段105を入力信号最適化手段106と中間層ニューロン数最適化手段107とに分けて構成したが、必要に応じて一方のみの構成とすることもできる。入力信号最適化手段106を除いた構成の場合、 $S_i \leftarrow S_i$ が省略される。また中間層ニューロン数最適化手段107を除いた構成の場合、 $S_i \leftarrow S_i$ が省略できる。また本実施例で入力信号最適化手段106には、入力信号の中から不要と判断されるものを次々と排除していく構成を採るが、入力信号の内容からこれらを容易に判別することにより信号数を減らすことも良い。さらに第12図に記載した各手段に同一の装置を接続した一体型の構成としても良いし、別個の装置としてソフトウェア等でデータを交換する形態としても良い。また判定手段104に備えたニューラルネットワーク演算制御手段500は必要に応じて省略し、ニューラルネットワーク演算手段100を使用して判定を行っ

ても良い。

次の実施例として第25図に、ニューラルネットワーク最適設計手段105の動作をユーザに知らせるための表示手段1101を設けた例を示す。表示手段1101では、入力信号最適化手段106で除かれた入力の番号や、中間層ニューロン数最適化手段107で決定された中間演算手段202のニューロン数をディスプレイ等に表示する。またこの他に学習の進行状況等を合わせて表示することもできる。

本発明の次の実施例として、演算量が最小のネットワークを設計する手法を示す。第26図はこれを実現するアルゴリズムであり、本実施例では、一見適当な構成に決定されたネットワーク（入力層ニューロン数 p 、中間層ニューロン数 m ）に対して、この構成を演算量最小化の観点からさらに最適化する例を示す。したがって本アルゴリズムは、例えば第17図の5.の後に実行すればよい。第26図において、まず、 p で入力量として適当なものを1つ追加することにより、入力層のニュー

ロンを1つ追加する。次に、 p で条件2.をける中間層ニューロンの最適数 m^* を決定する。最適数は第24図のアルゴリズムにより算出すれば良い。次に S_i で、 p と m の積と $(p+1) \times m^*$ の積の大小関係を比較する。 $p \times m > (p+1) \times m^*$ のとき、入力層ニューロン出力層ニューロンの数を減少させられ、したがってこれらの数の接続シナプス数が減少せられることになる。この場合には S_i で、 $p+1$ を p 、 m^* を m と置いた後、 S_i に戻り、以上の処理を繰返す。 S_i で、 $p \times m > (p+1) \times m^*$ でないとき、演算量の変更を最小化を図ることはできないため、入力層ニューロン数 p 、中間層ニューロン数 m のネットワークを最終的な構成に決定する。

本実施例では、入力層のニューロン数と中間層のニューロン数の値を最小化したが、さらに出力層のニューロン数を求じた値を最小化することもできる。

本実施例の次の実施例として、第27図にユーザにより与えられた学習環境を学習させる手法

を示す、N個の学習サンプルによる学習において、Sでこれらのもののおける出力層ニューロンの出力値と教師値との差分（エラー）が所定の閾値（ α ）以下に収まっているかどうかを調べる。そしてN個の学習サンプルのうち、

$$S_i = \frac{1}{N} \sum_{j=1}^N |e_j|$$
を満足するもののパーセンテージを算出する。Sでこのパーセンテージがユーザにより指定された値以下かどうかの判定を行う。以上の場合にはSで学習を打ち切る。パーセンテージに達していないときにはSで学習を継続する。本アルゴリズムは、学習中に適当なタイミング（通常学習は再帰的に行われるため、例えばN個の学習サンプルに対する演算が一区域したタイミング等）で実行し、学習の終了もしくは閾値を判定する。

本発明の次の実施例として、第1図の条件判定として学習時間が指定された場合のネットワーク設計手法を示す。ここでは、学習アルゴリズムとしてバックプロパゲーションアルゴリズム（例え

ば、ニューラルコンディターTM（東京電機大学出版局、合原一幸著）の式（15）～（18参照）を用いる場合について述べるがこれに限定されるものではない。

バックプロパゲーションアルゴリズムによる2つのシナプス結合の重みの修正に要する時間は、そのアルゴリズムを実行する手段（プログラムあるいはハードウェア）によって異なってしまう。また、ニューラルネットの全てのシナプス結合の重みを出力層から入力層に向けて1回だけ修正する時間は、ニューラルネットのシナプス結合の総数（以下、結合総数と呼ぶ）に比例する。

したがって、ニューラルネットの学習時間LTは、出力層から入力層に向けて重みを修正する回数（ここでは学習総数と呼ぶ）と結合総数を用いて、次式で表現することができる。

$$LT = T \times (\text{結合総数}) \times (\text{学習総数}) \quad \dots (44)$$

したがって、学習時間LTが指定された場合、重みの修正時間は既知であるので、結合総数と学習回数を用いておおよそに決定する

ばよい。決定する戦略としては、結合総数学習回数とも小さくなるように選ぶことが考えられる。第28図は、本実施例を実現する装置構成であり、第28図は第28図の装置で実行されるアルゴリズムである。第28図の装置構成は第12図の装置構成とはほとんど同一であるが、第28図では固定手段104から記憶手段103に向う信号を付加した所が特徴となっている。以下、第29図のアルゴリズムに従って説明する。第29図のアルゴリズムは固定手段104で実行され、T₀とT₁の値を算出する。T₀は、結合総数を小さく選ぶ方法であり、そのために入力信号の中心冗長な入力がないかを検出する。検出手段としては、第17図の入力信号変換手段101の機能T₁を用いればよい。冗長な入力信号が含まれていないことがわかっている場合は、学習時間LTをオペレータが指定するときに入力信号の冗長性の検出を行わないことを指定すればよい。

次に、T₁では学習回数を少なくする、学習回数を決定する要因は、前述した学習精度の他に学

習データの分散、重みの初期値、重みの修正式に用いられる学習定数（ η ）、安定化定数（ α ）などがあるが、これらのデータと学習回数との間に明確な関係式は存在しない。そこで、これらのデータと学習回数との関係を、例えば第29図に示すような学習回数データベースとして固定手段104から記憶手段103に登録するようにした。

T₁で結合総数が決まれば、(44)式より学習回数が決まる。そこで、検索手段104から記憶手段103から学習回数データベースを探索する。

(44)式で求めた学習回数に近いものを探索する。近いものがある場合、そのときの学習データの精度や学習データの個数などのパラメータを選択してニューラルネット演算手段102を用いて学習を行う。但し、学習データの個数は記憶手段103に格納されている学習データの個数と一致しない場合が生ずる。学習回数データベースから得られた学習データの個数が、記憶手段103に格納されている実学習データの個数より小さい場合は、実学習データから選択する必要がある。この選択

方法としては、各カテゴリー毎には区間数となるように実学習データから無作為に抽出する方法、あるいは各カテゴリー毎に入力信号の分布を求め、分布に比例して抽出する方法などが考えられる。

一方、(44)式で求めた学習回数に近いものが、学習回数データベースにない場合は、学習回数データベースの内容から推測して、学習精度、学習データ個数などのパラメータを決めればよい。このとき、実学習データ個数とに違いが出れば、前述した選択方法で実学習データから選択すればよい。

第30図の学習回数データベースには、当然のことであるが、本発明の装置を用いて学習を行う毎に追加が行われる。

第30図のデータベースに、ニューラルネットワークを構築するのに要した学習時間、ニューラルネットワークの規模(例えばシナプス結合の総数など)を登録することも可能である。この場合は、条件指定された学習時間と直接データベースを参照して、学習に必要なパラメータを指定することができる。

した出力の値を記憶する等の操作を、さらに行的とも良い。この後再構築指令発生手段1404は、記憶手段103の更新が終了したことを信号2により伝え、再構築指令発生手段1404はニューラルネットワーク再構築設計手段105を再起動する信号を、信号3により提示する。ニューラルネットワーク再構築設計手段105は、前述した処理を再度行うことにより、ニューラルネットワーク102の構成の最適化を行う。

次に本発明で考えられたニューラルネットワーク演算手段102が、各種システムに組込まれた例を示す。第32図は制御システムの制御ループの中に本装置が組込まれた例である。ニューラルネットワーク演算手段102は、制御対象1201からの帰還信号を入力とし、制御対象1201を駆動するための信号を出力する。

第33図はニューラルネットワーク演算手段102を、制御系1301のチューニング手段として用いた例である。102は制御対象1201からの帰還信号や、他のセンサからの信号を入力信号とし、

本発明の例の装置例として、第34図にニューラルネットワーク構築装置101とし、ニューラルネットワーク演算手段102の性能が所望でないときにこれを再構築する手段を追加した例を示す。ニューラルネットワーク再構築手段1401は、学習回数1403、教師データ更新手段1403、再構築指令発生手段1404からなり、性能評価手段1405はニューラルネットワーク演算手段102の再導入入力力、この入力に対する演算結果である出力を数値とし、出力が入力に対応した所望の値であるかどうかを評価する。評価はユーザが望ましい出力値を指定し、この値とニューラルネットワーク演算手段102との出力との差分を検出すれば容易に行える。評価結果が所望のレベルに達していないとき、性能評価手段1402により教師データ更新手段1403が信号1により起動され、差分の入力と入力力と、これに対応した望ましい出力の組合せを追加することで、記憶手段103の内容を更新する。このとき既に記憶手段103に蓄えられている入力のうち追加した入力に近い値の入力と、これに対応

制御系1301にとって最適な制御信号や各部の制御定数を出力信号とする。

第34図は制御対象1201、1202を含む制御系の発生部に適用した例である。ニューラルネットワーク演算手段102は、制御対象1201からの帰還信号や各種センサの信号を入力とし、制御対象1201に与える最適な制御信号を出力信号とする。この出力信号は制御対象1201からの対応した帰還信号と比較され、これらの偏差に对应した値が制御1401に入力される。1401はこれらの値を基に制御対象1201に出力する信号を演算により求める。追進信号との比較は必要に応じて省略し、フィードフォワード制御を行っても良い。

尚、上記制御対象としては、例えば昇降機、発電機プラント等をいう。

第35図は認識装置1501の主要部である。ニューラルネットワーク演算手段102は、認識対象1501からの情報を入力信号とし、認識結果を出力信号とする。認識対象1501としては、数字、文字、音声、人の顔、人間の感情、物体の色

やせらるゝ等、種々考えられる。認識結果は例えば数字の場合、認識結果表示装置16の2においてランプで表示することもできるし、ディスプレイや音声出力装置で表示してもよい。
〔発明の効果〕

以上説明した本発明の実施例の効果を説明する、

(イ) ニューラルネットの構築方法

従来のブラックボックスとしてしか扱えなかったニューラルネットが、本発明を実施することにより断片的に構築でき、しかも誤認識のおこりにくい構成とすることができ、

入力信号最適化手段を設けたことにより、ニューラルネット演算装置へ入力すべき信号を最も適切な形式に最適化できる。また中間層ニューロン数最適化手段を設けたことで、中間演算手段のニューロン数が最適な値に自動設定できる。以上2つの手段を設けたことにより、ニューラルネット演算手段の構成を簡易な演算で必要最小にできるので、従来行われていた試行錯誤的なシミュレーションを省略できる。またこれをハードで実現し

た場合には小形、安価、高速となり、ソフトで実現した場合には、高効率の演算が期待される。

また決定されたニューラルネットニューラルネット構築装置の演算内容を表示する手段を設けたことにより、ユーザインターフェイスが与えられる。

(ロ) ニューラルネットの重みのチューニング方法

従来の誤認識が生じるとき、誤認識が生じたデータを追加して再学習する方法しかなかったが、本発明を実施することにより、できあがったニューラルネットの重みをフィードバックすることにより誤認識が解消できる。

(ハ) ニューラルネット再構築方法

ニューラルネット再構築手段を設けたことにより、ニューラルネットの性能を装置の稼働状態を把握しながら、随時向上させられる。したがって装置の運用対象が経年変化等により動的に特性を愛する場合においても、本発明を問題なく適用できる。また完全な教師データを事柄に紐付けてお

なくて良いので、システム立上げが最適化される。

(ニ) 学習の高速化

従来広く用いられている逆伝播法は、教師データを個ずつ処理するために極めて収束が悪かったが本発明を実施することにより、高速化が可能となる。またその他の学習方法についても本発明を実施することにより高速化が可能である。

本発明をパターン認識予知等の様々なシステムに適用する際、ニューラルネットワークの解釈が行なえるため、誤認識誤った手続等に基づく誤認識誤った予知等が生じたとき容易に対応することが可能となる。

具体的なアプリケーションの例として画像認識システムにおける例を図3-6図に示す。図において車のナンバープレートは、工業用テレビで画像認識装置に取りこまれる。画像認識装置は、ナンバープレートの切り出しを行ない、その中から文字を1つずつ切り出し、文字画の特徴量を抽出する。抽出された特徴量は、ニューラルネットワークに入力され、その識別結果が出力される。

このニューロンの学習及び誤認識が生じたときのパラメータのチューニング及びネットワークの再構成に本発明を実施することにより、誤認識に強くかつ高速な学習を実現することが可能となる。

4. 図面の簡単な説明


第1図は本発明の一実施例、第2図は、ニューラルネットの構成例、第3図はシグモイド関数を示した図、第4図は、収束判定条件を説明した例、第5図は、2次元データのパターン分離の例、第6図は、第5図のパターンを分離するニューラルネットを示した図、第7図は、最適化の手段を示した図、第8図は、ニューラルネットワークを構成する方法を説明した図、第9図は重みのチューニング法を説明した図、第10図は学習の高速化を説明した図、第11図は第10図の方法で学習した例を示す図、第12図は本発明の他の一実施例の構成例、第13図乃至第14図は、ニューラルネット演算の説明図、第15図は教師データの例、第16図は判定手段の説明図、第17図はアルゴリズム、第18図乃至第20図は入力信号最適化

手段の順度の説明図、第21図は入力信号最適化手段の別の実施例、第22図乃至第23図は、第21図の方式を説明した図、第24図は、アルゴリズム、第25図は構成図、第26図は、演算量最小の条件でネットを構成する実施例、第27図は学習精度を高くして、ネットを構成する実施例、第28図は指定演算時間内にネットを構成する実施例、第29図乃至第30図は、第28図の方式を説明する図、第31図はネットを再構築する実施例、第32図乃至第33図は本発明を適用したシステムの構成図、第34図は実施例に適用した例である。



- 11…ニューラルネットを構築するステップ、
 12…パラメータをチューニングするステップ、
 101…ニューラルネット構築装置、102…ニューラルネット演算手段、103…記憶手段、
 104…設定手段、105…ニューラルネット系最適設計手段、106…入力信号最適化手段、
 107…中間層ニューロン最適化手段、108…表示手段。

代理人 弁理士 小川勝男


第 1 図




第 2 図




第 4 図




第 5 図




第 6 図



第 7 図



第 8 図



第 9 図







図 10 図


第 10 図




第 12 図



第 14 図




第 13 図



第 15 図

層	入力層 (Input Layer)			出力層 (Output Layer)		
	x1	x2	...	T1	T2	...
1	0.5	0.32	...	0.9	0.7	...
2	0.7	0.67	...	0.8	0.5	...
...
N	0	0.12	...	0.1	0.01	...


第 21 図



第 20 図



第 22 図



第 24 図




Y = A * H * I * J * K * L * M * N * O * P * Q * R * S * T * U * V * W * X * Y * Z


426

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99
0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99


25 52




22




第 27 図




第 28 図




第 29 図




第 30 図




第 34 図



第 35 図



第 36 図



第1頁の続き

発明者	武 張 寛	茨城県日立市久慈町4026番地 研究所内	株式会社日立製作所日立研
発明者	諸 岡 泰 男	茨城県日立市久慈町4026番地 研究所内	株式会社日立製作所日立研
発明者	川 上 樹 三	茨城県日立市久慈町4026番地 研究所内	株式会社日立製作所日立研
発明者	高 藤 政 道	茨城県日立市久慈町4026番地 研究所内	株式会社日立製作所日立研